

Deep Learning 的适用场景及可视化结合的思考

引言

周三至周五与实验室范围内对 deep learning（以下简称 DL）有研究的学长们请教并讨论了关于使用 DL 辅助可视化任务的问题，并对目前可视化领域内适用 DL 解决的问题做了一部分梳理。

Deep learning 的现有应用及适用场景

Deep neural network 常见方法（网络结构）主要有 CNN、RNN 与 LSTM 三种。CNN 主要用于静态数据，RNN 与 LSTM 可用于识别时序信息。DL 对适用问题的限制和自身特征有以下几点：

- Deep neural network 对输入数据的 size 有很高限制，要求训练与预测数据的尺寸必须一致，例如图片长宽、词频向量长度等。
- 训练数据数目至少需要千级别的数据。对于图片分类任务普遍采用万级别以上的训练数据量。
- LSTM 或 3D CNN 可以很好地捕捉时序帧（或视频）中特征的动态演变。

关于力引导布局问题套用 DL 的适配性问题

经过查阅文献(Andrychowicz et al., 2016; Henaff, Bruna, & LeCun, 2015)及讨论，目前 DL 还无法将 graph 结构作为输入。并且由于力引导布局本质是一个优化问题，暂时无法直接套用已有的 DL 网络结构及应用任务。

可能适用的可视化问题

基于上述内容，下面列出了可使用 DL 方法的可视化问题的特征：

1. 问题的本质是一个识别/分类问题：可以直接套用现有 DL 的方法与任务。
2. 用户基于可视化结果可以很快进行识别：至少证明人是可以做到的。
3. 某些场景下生成的可视化结果数目庞大，用户全部浏览的成本极高；发挥自动方法的优势。
4. 以可视化结果的 image 作为分析对象：可以直接当成一个 computer

vision 问题。这里的 Image 也可以是栅格化后的矩阵

- 5. 训练数据及相应标记容易获得：这也是目前最大的障碍之一。

潜在研究问题：散点图识别

- **问题描述：**散点图上点的分布特征识别。对于高维数据，散点图矩阵等可视化方法会产生用户难以应付的散点图数量，
- **现有工作：**Scagnostics(Wilkinson, 2014; Wilkinson, Anand, & Grossman, 2005)是可视化领域主要的散点图特征描述之一，图 1 列出了 scagnostics 中定义的所有散点图特征。后续工作从很多方面对其进行拓展，如(Dang, Anand, & Wilkinson, 2013)将 scagnostics 拓展到时序散点图；(Behrisch, Korkmaz, Shao, & Schreck, 2014)使用决策树捕捉用户希望得到的 scagnostics 特征分布，进而对已有的大量散点图进行过滤。

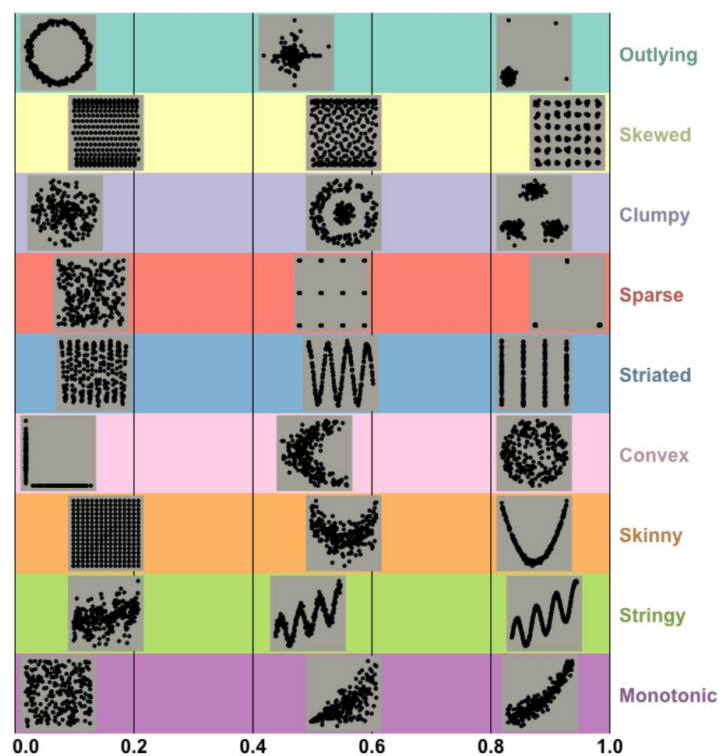


Figure 2: Example scatterplots and their scagnostics measures.

图 1 九种定义好的 scagnostics 特征

- **不足：**已有的 scagnostics 方法的不足：1) 速度慢，需要计算散点图内所有点的 alpha shape、最小生成树等结构。2) 并不考虑复杂问题，如多类散点图等。3) (待补充)

- **对我们的优势：**1) 问题本身是一个识别问题。2) 某些场景下散点图数目庞大，例如 SeeDB、寻找最优的投影等。3) 训练数据容易获得，可由传统的 scagnostics 方法直接生成。

下一步计划

- 完善散点图识别问题的定义。
- 寻找更多可能的潜在问题并评估可行性。

引用

- Andrychowicz, M., Denil, M., Gomez, S., Hoffman, M. W., Pfau, D., Schaul, T., & de Freitas, N. (2016). Learning To Learn by Gradient Descent by Gradient Descent. *NIPS*, 1–16. Retrieved from <http://arxiv.org/abs/1606.04474>
- Behrisch, M., Korkmaz, F., Shao, L., & Schreck, T. (2014). Feedback-driven interactive exploration of large multidimensional data supported by visual classifier. *2014 IEEE Conference on Visual Analytics Science and Technology (VAST)*, 43–52. <http://doi.org/10.1109/VAST.2014.7042480>
- Dang, T. N., Anand, A., & Wilkinson, L. (2013). TimeSeer: Scagnostics for high-dimensional time series. *IEEE Transactions on Visualization and Computer Graphics*, 19(3), 470–483. <http://doi.org/10.1109/TVCG.2012.128>
- Henaff, M., Bruna, J., & LeCun, Y. (2015). Deep Convolutional Networks on Graph-Structured Data. *arXiv*, 1–10. Retrieved from <http://arxiv.org/abs/1506.05163>
- Wilkinson, L. (2014). ScagExplorer: Exploring Scatterplots by Their Scagnostics. *2014 IEEE Pacific Visualization Symposium*, 73–80. <http://doi.org/10.1109/PacificVis.2014.42>
- Wilkinson, L., Anand, A., & Grossman, R. (2005). Graph-theoretic scagnostics. *IEEE Symposium on Information Visualization INFOVIS*, 157–164. <http://doi.org/10.1109/INFVIS.2005.1532142>